

**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU  
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I  
INFORMACIJSKIH TEHNOLOGIJA OSIJEK**

**Sveučilišni studij**

**Ocjena kvalitete video signala metrikama koje ne  
zahtijevaju pristup referentnom signalu**

**Završni rad**

**Sebastian Schneider**

**Osijek, 2017**

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA  
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****Obrazac Z1P - Obrazac za ocjenu završnog rada na preddiplomskom sveučilišnom studiju**

Osijek, 21.09.2017.

Odboru za završne i diplomske ispite

**Prijedlog ocjene završnog rada**

Ime i prezime studenta:	Sebastian Schneider
Studij, smjer:	Prediplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	3957, 18.07.2014.
OIB studenta:	32520755842
Mentor:	Doc.dr.sc. Mario Vranješ
Sumentor:	
Sumentor iz tvrtke:	
Naslov završnog rada:	Ocjena kvalitete video signala metrikama koje ne zahtijevaju pristup referentnom signalu
Znanstvena grana rada:	<b>Telekomunikacije i informatika (zn. polje elektrotehnika)</b>
Predložena ocjena završnog rada:	Vrlo dobar (4)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 2 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 2 bod/boda Jasnoća pismenog izražavanja: 2 bod/boda Razina samostalnosti: 2 razina
Datum prijedloga ocjene mentora:	21.09.2017.
Datum potvrde ocjene Odbora:	27.09.2017.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis: Datum:



**FERIT**

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA  
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK**

## IZJAVA O ORIGINALNOSTIRADA

Osijek, 27.09.2017.

Ime i prezime studenta:

Sebastian Schneider

Studij:

Preddiplomski sveučilišni studij Elektrotehnika

Mat. br. studenta, godina upisa:

3957, 18.07.2014.

Ephorus podudaranje [%]:

6

Ovom izjavom izjavljujem da je rad pod nazivom: **Ocjena kvalitete video signala metrikama koje ne zahtijevaju pristup referentnom signalu**

izrađen pod vodstvom mentora Doc.dr.sc. Mario Vranješ

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

## Sadržaj

1. UVOD .....	1
1.1 Zadatak završnog rada .....	1
2. OCJENA KVALITETE VIDEO .....	2
2.1. Metode ocjene kvalitete video signala .....	2
2.2. Subjektivne i objektivne metode .....	2
2.3. Podjela objektivnih metrika prema zahtijevu za informacijama o referentnom signalu .....	3
3. NR METRIKE ZA OCJENU KVALITETE VIDEO SIGNALA .....	5
3.1. NR metode zasnovane na elementu slike .....	5
3.2. NR metoda zasnovana na toku bita .....	8
3.3. Hibridne NR metode .....	8
4. USPOREDBA REZULTATA ODABRANIH NR METRIKA .....	10
4.1. Opis baze video signala .....	10
4.2. Rezultati metrika .....	11
4.2.1. Rezultati subjektivne metrike .....	11
4.2.2. Dobivanje rezultata BRISQUE metrikom .....	11
4.2.3. Dobivanje rezultata MSU Blocking i MSU Blurring metrikama .....	12
4.3. Diskusija o rezultatima .....	16
5. ZAKLJUČAK .....	18
LITERATURA .....	19
POPIS I OPIS UPOTRIJEBLJENIH KRATICA .....	22
SAŽETAK .....	23
ŽIVOTOPIS .....	25

# 1. UVOD

Brzi napredak tehnologije omogućuje sve veću uporabu video zapisa i slika kao sredstava za komunikaciju. Prilikom prijenosa video zapisa od pošiljatelja do gledatelja razne operacije mogu uzrokovati izobličenja video zapisa. Video zapis se prije prijenosa komprimira radi korištenja manje širine kanala, ali se na taj način izobličuje. Pri prijenosu se unose izobličenja poput šuma, zamućivanja i dr. Zbog tih izobličenja važno je video zapis provjeriti prije nego što se prikaže krajnjem korisniku. U svrhu provjeravanja video zapisa razvijena je tehnička grana za procjenu kvalitete video zapisa VQA (engl. *Video Quality Assessment*). Glavna je tema završnog rada objasniti metrike za ocjenjivanje kvalitete video signala. Kvalitetu video zapisa moguće je ocjenjivati objektivnim i subjektivnim metodama. Objektivne metode koriste se računalima, a subjektivne metode ljudima kao ocjenjivačima. Jednu podskupinu objektivnih metoda čine objektivne metode koje pri ocjeni kvalitete video signala ne zahtijevaju pristup referentnom signalu (engl. *no reference*, NR).

U ovom radu usporedit će se tri metrike za ocjenjivanje video signala koje ne zahtijevaju pristup referentnom signalu. U glavnom dijelu rada opisane su BRISQUE (engl. *Blind/Referenceless Image Spatial QUality Evaluator*), MSU Blocking i MSU Blurring metrike koje su korištene za ocjenjivanje video signala, u eksperimentalnom dijelu tog rada.

## 1.1 Zadatak završnog rada

U radu je potrebno dati detaljan pregled stanja NR metrika za ocjenu kvalitete videa koristeći dostupnu literaturu. Koristeći algoritme nekoliko javno dostupnih NR metrika potrebno je načiniti usporedbu performansi tih metrika na zadanom skupu video signala.

## **2. OCJENA KVALITETE VIDEO**

### **2.1. Metode ocjene kvalitete video signala**

Istraživanje vezano za ocjenu kvalitete video signala već je duže vrijeme u centru pažnje velikog broja ljudi koji rade na području videoindustrije. Problemi s kojima se susreće video industrija su kako mjeriti kvalitetu isporučenog video sadržaja, kako garantirati određenu razinu kvalitete isporučenog video sadržaja te kako potvrditi da je video sadržaj isporučen uz obećanu razinu kvalitete.

Najopćenitija podjela metoda za ocjenu kvalitete video signala je ona na subjektivne i objektivne metode. Subjektivna metoda koristi ljude tj. gledatelje za određivanje ocjene kvalitete video signala, dok se kod objektivne metode koriste računalni algoritmi u svrhu ocjene kvalitete video signala. Kod objektivne metode eliminira se potreba za ljudskim resursima.

### **2.2. Subjektivne i objektivne metode**

Subjektivna metoda za ocjenjivanje kvalitete video signala koristi ljude (subjekte) tj. skupinu gledatelja koji daju ocjenu kvalitetu video signala koji je izobličen na odgovarajući način. Takav postupak daje najpreciznije i najpouzdanije ocjene kvalitete video signala, ali zahtijeva puno vremena i ljudskih resursa. Upravo su ljudi ti koji su krajnji korisnici video sadržaja tj. video usluga. Rezultati subjektivne metode koriste se kao referenca za ispitivanje performansi objektivnih metrika.

Kod subjektivnih eksperimenata veći broj gledatelja (najmanje 15, obično 15-30) [1] gleda skup video signala i ocjenjuje njihovu kvalitetu. Za proračun ukupne ocjene kvalitete video signala koriste se sve ocjene gledatelja koje su dodijelili tom video signalu. Način proračunavanja unaprijed je propisan. Svaka osoba ima drugačije očekivanje i interese pri gledanju određenog video signala. Subjektivnost ocjena gledatelja ne može se u potpunosti eliminirati. Subjektivni eksperimenti nastoje smanjiti učinke tih faktora pomoću preciznih upita, kontrolirane okoline i provođenja trening sesija. Treba napomenuti da je mjerenje kvalitete video signala mjerenje sa šumom koje je definirano statističkom raspodjelom. Neke od metoda su metoda jednostrukog podražaja (engl. *Single Stimulus* - *SS*) i metoda dvostrukog podražaja (engl. *Double Stimulus* – *DS*) [1].

Za razliku od subjektivne metode gdje ljudi (subjekti) ocjenjuju kvalitetu video signala, objektivna metoda koristi matematičke modele s ciljem da automatski predvidi kvalitetu video signala i ukloni potrebu za ljudskim resursima. Također objektivne metode mjerenja kvalitete video signala su jeftinije te ih je lakše provesti. Objektne metode koriste različite pristupe i stoga mogu biti razvrstane na nekoliko načina.

### **2.3. Podjela objektivnih metrika prema zahtijevu za informacijama o referentnom signalu**

Objektivne metrike koje se koriste za određivanje ocjene kvalitete video signala mogu imati zahtjeve za različitom količinom informacija o referentnom video signalu. Objektivne metrike raspodjeljuju se u tri kategorije: metrike koje zahtijevaju da je cjelokupni video signal dostupan i neoštećen (engl. *full-reference*-FR), metrike koje zahtijevaju dostupnost samo nekih značajki referentnog signala (engl. *reduced-reference*-RR) i metrike koje ne zahtijevaju dostupnost informacije o referentnom signalu (engl. *no-reference*-NR).

FR metrike koriste referentni i izobličeni video signal te provode usporedbu između referentnog i izobličenog signala. Ta dva video signala trebaju biti prostorno i vremenski usklađena (svaki element slike u svakom okviru referentnog signala mora biti usklađen s odgovarajućim elementom okvira izobličenog signala). Zahtjevi za dostupnošću referentnog signala i izobličenog signala i poravnanjem referentnog signala glavne su mane takvih metrika s gledišta praktičnog korištenja u stvarno-vremenskim sustavima. Najpoznatije FR metrike su srednja kvadratna pogreška (engl. *Mean Squared Error* - MSE) i vršni odnos signala i šuma (engl. *Peak Signal to Noise Ratio*- PSNR). Postoje mnogo naprednije i uspješnije FR metrika od MSE i PSNR, a više detalja o nekim od njih može se naći u [2-12].

RR metrike izdvajaju neke značajke referentnog video signala (npr. prostorne detalje ili količina pokreta) i uspoređuju izobličeni i referentni signal na osnovu tih značajki. RR metrike zapravo su kompromis između FR i NR metrika. Ovim metrikama moguće je upravljati količinom informacija o referentnom video signalu. Također ove metrike zahtijevaju usklađivanje referentnog i izobličenog signala, ali samo za određene značajke [13-18].


NR metrike samo analiziraju izobličeni video signal bez potrebe za informacijama o referentnom signalu. Iz tog razloga pogodne su za stvarno-vremenske sustave te se mogu koristiti bilo gdje u postojećem prijenosnom i kompresijskom sustavu gdje nije dostupan

referentni video signal. Najčešće korišten proces kod NR metrika je procjena artefakta stvaranja blokova, koji nastaje pri korištenju najčešćih metoda kompresije poput H26x, MPEG [19-23].



### 3. NR METRIKE ZA OCJENU KVALITETE VIDEO SIGNALA

NR metode određuju ocjenu kvalitete video sadržaja tako da ne zahtijevaju pristup referentnom signalu. Zbog činjenice da nemaju pristup izvornom odnosno referentom signalu one mogu biti manje precizne od FR i RR metrika, ali su zato pogodnije za stvarno- vremenske sustave. NR metrike dijele se na one zasnovane na elementu slike (engl. *Pixel-Based Methods - NR-P*), metode koje su zasnovane na analizi parametara i toku bita (engl. *Parametric/Bitstream Methods -NR-B*) i hibridne metode (engl. *Hybrid Methods - NR-H*) [24]. Na slici 3.1 prikazana je podjela NR metrika.




Sl. 3.1. Podjela NR metrika [24]

#### 3.1. NR metode zasnovane na elementu slike

NR-P metode koriste dekodiranu reprezentaciju signala i analizu kvalitete temeljenu na informacijama o elementima slike. Neke od njih određuju ocjenu samo specifične vrste degradacije kao što su zamućenje, efekt stvaranja blokova, šum ili drugi artefakti kodiranja [24]. Neke od NR-P metoda su BRISQUE (engl. *Blind/Referenceless Image Spatial Quality Evaluator*) [26], MSU Blocking i MSU Blurring [27].

BRISQUE je NR metrika za procjenu kvalitete slike (engl. *image quality assessment-IQA*). BRISQUE metrika ne izračunava značajke specifične za izobličenje kao što su zvonjenje, zamagljivanje ili efekt blokiranja, već umjesto toga upotrebljava statistiku scena lokalno normaliziranih koeficijenata svjetline za kvantificiranje mogućih gubitaka "prirodnosti" na slici zbog prisutnosti iskrivljenja što dovodi do holističke mjere kakvoće. Unatoč svojoj jednostavnosti može se pokazati da je BRISQUE statistički bolja od FR metoda kao što su PSNR [34] i SSIM [35] te je vrlo primjenjiva za sva današnja izobličenja slike i videa. BRISQUE ima vrlo nisku računalnu složenost što ju čini prikladnom za aplikacije u stvarnom vremenu. BRISQUE značajke mogu se koristiti i za identifikaciju izobličenja [26].

MSU Bluring i MSU Blurring su metrike dostupne unutar MSU alata za ocjenu kvalitete video signala [27]. MSU alat za mjerenje kvalitete videa (engl. *MSU Video Quality Measurement Tool-VQMT*) je program za objektivnu procjenu kvalitete videa. Pruža funkcionalnost za FR, RR i NR metode. Osnovna shema alata ilustrirana je na slici 3.2. [27].



**Sl. 3.2.** Osnovna shema VQMT alata [27]

Ocjena kvalitete video zapisa je obilježje video zapisa koji prolazi kroz sustave za prijenos i obradu video zapisa, formalna i neformalna mjera opaženog pogoršanja video zapisa. Sustavi za obradu video zapisa mogu uvesti neke količine izobličenja ili artefakata u video signal pa je ocjena kvalitete video zapisa vrlo važna. MSU VQMT program je namijenjen za mjerenje kvalitete video zapisa [27].

MSU Blocking metrika (engl. *MSU Blocking metric*) izrađena je za mjerenje subjektivnog efekta blokiranja u video zapisu. Na primjer, u kontrastnim područjima efekt blokiranja nema utjecaja, ali u glatkim područjima rubovi okvira su primjetljivi. Ova metrika također sadrži heurističku metodu za otkrivanje rubova objekata koji su postavljeni na rub bloka. U ovom slučaju vrijednost koju daje metrika se smanjuje kako bi se omogućilo preciznije mjerenje efekta blokiranja. Koriste se podaci prethodnih okvira kako bi postigli veću točnost [27].




a)

b)

**Sl. 3.3.** Primjer; a) okvir video zapisa, b) MSU Blocking za dani okvir [27]

MSU Blurring metrika (engl. *MSU Blurring Metric*) omogućuje usporedbu količine zamućivanja između dviju slika. Ako je vrijednost metrike za prvu sliku veća nego za drugu sliku, to znači da je druga slika zamućenija nego prva [27].



a)

b)

c)

**Sl. 3.4.** Primjer; a) izvorna slika, b) obrađena slika, c) rezultat MSU Blurring metode [27]

### 3.2. NR metoda zasnovana na toku bita

NR-B metode upotrebljavaju značajke uzete iz toka bita kao što su zaglavlje paketa (MPEG-TS), pokretnih vektora i parametara kvantizacije. Nemaju pristup referentom odnosno izvornom signalu i ne zahtijevaju dekodiranje video zapisa što ih čini učinkovitijima. Za razliku od NR-P metodama nemaju pristup konačnom dekodiranom signalu [24]. Neke od NR-B metoda su dane u [28-30].

NR metrika zasnovana je na parametru varijacije kašnjenja paketa (engl. *Packet Delay Variation-PDV*) dana je u [28]. U ovoj metodi predložen je prototip metrike za ocjenu kvalitete video signala koji se zasniva na općim značajkama uočenim za degradacije kvalitete video zapisa uzrokovanim PDV-om [28].

NR metrika za procjenu kvalitete video zapisa zasnovana je na H.264/AVC toku bita opisana je u [29]. Provodi ekstrakciju značajki iz H.264/AVC kodiranog toka bita. Nakon ekstrakcije značajki koje su vrlo važne za procjenu kvalitete video sadržaja upotrebljava se PLSR (engl. *Partial Least Squares Regression*) [29].

Jednostavna metrika za određivanje ocjene kvalitete video sadržaja zasnovana je na toku bita za H.264/AVC video sadržaj obrađena je u [30]. Ima malu računalnu složenost za procjenu kvalitete H.264 kodiranih video sadržaja. Ova NR metrika provodi moduliranje kodiranog izobličenja pomoću tri parametra toka bita, a parametri su frekvencija okvira, vektor pokreta i parametar kvantizacije [30].

### 3.3. Hibridne NR metode

Hibridne NR-H metode kombiniraju značajke uzete iz toka bita s dekodiranim signalom. One su stoga mješavina između NR-P i NR-B metoda [24]. Neke od NR-H su BLIINDS [31], BLIINDS II [32] i DIIVINE [33].

BLIINDS (engl. *BLind Image Integrity Notator using DCT Statistics*) je NR pristup procjeni kvalitete slike koji ne pretpostavlja određenu vrstu izobličenja slike. Zasniva se na predviđanju kvalitete slike temeljem promatranja statističkih podataka lokalnih diskretnih koeficijenata kosinusne transformacije i zahtijeva samo minimalnu obuku [31].

BLIINDS II je algoritam koji koristi NSS (engl. *natural scene statistics*) pristup u DCT (engl. *Discrete cosine transform*) domeni za procjenu kvalitete slike i videa bez referentne slike. BLIINDS II usvaja jednostavan model za dobivanje rezultata. S obzirom na izvađene značajke ispitane slike/video sadržaja, ocjena kvalitete koja maksimizira vjerojatnost empirijski

određenog modela zaključivanja odabrana je kao predviđeni rezultat kvalitete slike/video sadržaja [32].

DIIVINE (engl. *Distortion Identification-based Image Verity and INtegrity Evaluation*) je metrika koja se temelji na dvostupanjskom okviru koji uključuje identifikaciju izobličenja praćenu procjenom kakvoće specifične za izobličenje. DIIVINE je sposobna procijeniti kvalitetu izobličene slike za više tipova izobličenja. DIIVINE se temelji na statistici prirodne scene [33].

## 4. USPOREDBA REZULTATA ODABRANIH NR METRIKA

U ovom poglavlju opisan je eksperimentalni dio rada. Uspoređene su tri NR metrike javno dostupne znanstvenoj zajednici besplatno. Upravo je to bio kriterij za odabir metrika za usporedbu. Tako su odabrane metrike za usporedbu BRISQUE, MSU Blocking i MSU Blurring.

### 4.1. Opis baze video signala

Testiranje BRISQUE, MSU Blocking i MSU Blurring metrike izvodi se na LIVE video bazi koja je javno dostupna baza. Video sadržaji iz LIVE baze su u YUV 4:2:0 formatu i ne sadrže nikakva zaglavlja. Rezolucija svih video sadržaja je 768x432 elemenata slike. LIVE baza videa sadrži 10 različitih video sadržaja (kao što je prikazano u tablici 4.1.) i za svaki sadržaj postoji 16 video signala, od kojih je jedan originalan video zapis ('1'), 4 su izobličena prijenosom bežičnim mrežama ('2', '3', '4', '5'), 3 su izobličena prijenosom IP mrežama ('6', '7', '8'), 4 su izobličena H.264kompresijom ('9', '10', '11', '12') i 4 su izobličena MPEG-2 kompresijom ('13', '14', '15', '16'). Video zapisi imaju 25 ili 50 okvira u sekundi (25fps ili 50fps) (engl. *frames per second*). Video zapisi se imenuju po sljedećem uzorku - "xx#\_\$fps.yuv", gdje xx predstavlja kraticu za sadržaj videa (koji su prikazani u tablici 4.1), # predstavlja vrstu iskrivljenja i \$ predstavlja broj okvira u sekundi. Ukupno u bazi postoji 160 video signala. Video signali s kraticama "pa", "rb", "rh", "sf", "sh", "st" i "tr" ima 250 okvira ( 25fps ), video signal "bs" ima 217 okvira ( 25fps ) i video signali s kraticama "mc", "pr" i "sh" imaju 500 okvira ( 50fps ) [36]. U ovom radu koristit će se video zapisi koji imaju IP i H.264 tipove izobličenja.

Tab. 4.1. Popis kratica i sadržaja LIVE video baze

Kratica imena videa	Puno ime videa
bs	Plavo nebo
mc	Mobilni i kalendar
pa	Pješačka zona
pr	Trčanje parkom
rb	Riječno korito
rh	Prometna gužva
sf	Suncokret
sh	Štitovi
st	Stanica
tr	Traktor

## **4.2. Rezultati metrika**

### **4.2.1. Rezultati subjektivne metrike**

Subjektivno određivanje kvalitete video zapisa provodi se pomoću promatrača koji po točno određenom postupku određuje ocjenu kvalitetu video zapisa. Subjektivno određivanje ocjene kvalitete video zapisa iz LIVE baze određeno je na način da subjekt uspoređuje izobličeni video zapis s referentnim video zapisom. Određivanje ocjene napravljeno je u 2 sesije po pola sata. Video zapisi naizmjenično su prikazivani subjektima tako da subjekt ne zna koji točno video zapis promatra. Ocjena kod subjektivne metrike je u rasponu od 0 do 100 gdje 0 predstavlja najbolju, a 100 najgoru ocjenu. Rezultati ocjene kvalitete video zapisa iz LIVE baze označeni su s MOS i prikazani su utablici 4.2. [36].

### **4.2.2. Dobivanje rezultataBRISQUE metrikom**

Rezultati BRISQUE metrike dobiveni su na sljedeći način. Prvo korištenjem funkcije *save\_yuvframe.m* [37] sprema se određen okvir video zapisa te se zatim pokreće funkcija *brisquescore.m* [26] koja određuje ocjenu kvalitete tog okvira. Ocjena kvalitete video zapisa je srednja vrijednost svih ocjena za pojedinačne okvire video zapisa. Kod korišten za izračunavanje srednje vrijednosti ocjena svakog okvira nalazi se kasnije u tekstu. Ocjena kod BRISQUE metrike je u rasponu od 0 do 100 gdje 0 predstavlja najbolju, a 100 najgoru ocjenu. Rezultati ocjene kvalitete video zapisa BRISQUE metrikom za LIVE bazu nalaze se u tablici 4.2.


### Matlab kod za određivanje ukupne ocjene BRISQUE metrikom:

```
clc; clear; close all;
A=1;
sr=0;
C=[];
frame=250; %broj okvira u video zapisu
for A = 0:1:(frame-1);
    C = save_yuvframe('sh12_50fps.yuv',[768 432],A,'test.png');
    image = rgb2gray(C);
    qualityscore = brisquescore(image);
    sr=sr+qualityscore;
    A;
end
srqualityscore=sr/frame;
```


### 4.2.3. Dobivanje rezultata MSU Blocking i MSU Blurring metrikama

Rezultati MSU Blocking i MSU Blurring metrike dobivene su korištenjem programa MSU Video Quality Measurement Tool. Program određuje ocjenu kvalitete za pojedinačni okvir za određeni video zapis. Ocjena kvalitete video zapisa srednja je vrijednost svih ocjena za pojedinačni okvir. Na slikama 4.1. i 4.2. prikazano je sučelje programa MSU Video Quality Measurement Tool i njegova osnovna obilježja. Ocjena kod MSU Blocking metrike je u rasponu od 0 do 100 gdje 0 predstavlja najbolju, a 100 najgoru ocjenu. Kod MSU Blurring metrike raspon je od 0 do 100 gdje 100 predstavlja najbolju, a 0 najgoru ocjenu. Rezultati za MSU Blocking i MSU Blurring metriku nalaze se u tablici 4.2. [27].





**Sl. 4.1.** MSU Video Quality Measurement Tool; odabir video zapisa na kojem će se odrediti ocjena kvalitete pomoću određene metode [27]



**Sl. 4.2.** MSU Video Quality Measurement Tool; odabir odgovarajuće metrike [27]

**TABLICA 4.2.** Rezultati odabranih NR metrika za signale s IP i H.264 tipovima izobličenja iz LIVE baze video signala

Naziv video signala	BRISQUE	MSU Blocking	MSU Blurring	MOS	Tip izobličenja
bs6_25fps	27,3732	14,2551	19,2964	61,7965	IP
bs7_25fps	32,7788	13,9427	19,0634	45,9273	IP
bs8_25fps	32,8709	13,7985	19,1036	40,9576	IP
bs9_25fps	32,2005	13,3474	19,5744	31,9421	H.264
bs10_25fps	32,8244	13,6957	19,2230	36,6396	H.264
bs11_25fps	33,4159	14,2067	18,7203	38,6448	H.264
bs12_25fps	34,4383	15,0251	17,7757	52,1844	H.264
mc6_50fps	26,4516	23,4413	15,9808	73,3075	IP
mc7_50fps	34,4301	24,7718	15,6110	58,5392	IP
mc8_50fps	34,8320	24,8462	15,4681	54,0963	IP
mc9_50fps	35,7407	25,2360	15,1266	47,3711	H.264
mc10_50fps	36,1144	25,4119	14,9547	48,7705	H.264
mc11_50fps	36,8597	26,2359	14,5114	57,6788	H.264
mc12_50fps	39,5913	28,3399	13,3932	67,8232	H.264
pa6_25fps	43,5521	22,5419	8,3428	73,8803	IP
pa7_25fps	50,6155	25,2909	7,8576	63,2564	IP
pa8_25fps	52,1638	25,3016	7,6105	61,2726	IP
pa9_25fps	53,7513	24,4770	7,2730	40,5551	H.264
pa10_25fps	54,8648	24,9283	6,8388	52,6111	H.264
pa11_25fps	55,2809	25,6853	6,4868	60,2534	H.264
pa12_25fps	55,2392	25,2725	6,2367	68,7186	H.264
pr6_50fps	21,1063	11,4975	30,2243	55,3240	IP
pr7_50fps	19,4800	11,1303	31,7515	56,1730	IP
pr8_50fps	20,5225	11,4778	30,2160	44,6086	IP
pr9_50fps	20,6258	11,8629	30,4506	39,8067	H.264
pr10_50fps	23,1106	12,7979	28,9249	53,7598	H.264
pr11_50fps	25,5665	13,3444	27,5568	59,8921	H.264
pr12_50fps	31,6372	15,2292	24,4514	77,2518	H.264
rb6_25fps	59,0145	28,6036	11,3266	68,1064	IP
rb7_25fps	56,7107	25,3674	12,8304	54,8101	IP
rb8_25fps	57,5387	26,3024	12,1932	54,6555	IP
rb9_25fps	59,1549	28,5605	11,1388	39,1978	H.264
rb10_25fps	59,5620	30,6432	10,3629	43,6833	H.264
rb11_25fps	59,0922	32,8079	9,1696	55,8563	H.264
rb12_25fps	59,2090	33,3908	8,4588	63,5809	H.264

rh6_25fps	48,9326	28,3905	7,1963	55,2291	IP
rh7_25fps	43,8564	29,2551	7,5530	62,3778	IP
rh8_25fps	48,2500	27,8573	7,3262	42,6909	IP
rh9_25fps	52,2826	28,7871	6,7621	37,8713	H.264
rh10_25fps	53,3333	28,6136	6,5698	45,4363	H.264
rh11_25fps	54,2500	28,9961	6,4496	53,6343	H.264
rh12_25fps	55,6290	28,7089	6,2723	62,9934	H.264
sf6_25fps	49,6329	26,2535	12,1351	59,3959	IP
sf7_25fps	47,9232	22,9918	12,6830	44,8094	IP
sf8_25fps	49,9220	25,2567	12,3666	39,1088	IP
sf9_25fps	49,5286	23,9332	12,6315	32,6002	H.264
sf10_25fps	50,6243	26,1998	12,0516	44,0164	H.264
sf11_25fps	50,7780	26,9501	11,8660	54,9423	H.264
sf12_25fps	51,1234	27,5520	11,6076	57,1497	H.264
sh6_50fps	23,1616	16,0283	18,6602	55,5307	IP
sh7_50fps	21,8529	14,1526	18,9619	61,2837	IP
sh8_50fps	23,5666	15,9728	18,7613	46,2254	IP
sh9_50fps	22,9254	15,9412	18,6737	36,2440	H.264
sh10_50fps	24,6712	15,9536	18,2478	40,8004	H.264
sh11_50fps	26,1157	15,9667	17,8134	51,6153	H.264
sh12_50fps	28,1317	16,0410	17,1200	66,3166	H.264
st6_25fps	16,8958	18,3413	8,8680	59,3959	IP
st7_25fps	18,1815	18,7726	8,6067	44,8094	IP
st8_25fps	16,8244	18,2693	8,8870	39,1088	IP
st9_25fps	19,5445	19,4843	8,2914	32,6002	H.264
st10_25fps	20,0203	19,7021	8,1383	44,0164	H.264
st11_25fps	20,5748	19,9641	7,9833	54,9423	H.264
st12_25fps	21,2133	20,2090	7,8247	57,1497	H.264
tr6_25fps	40,9723	21,2220	15,1634	73,4730	IP
tr7_25fps	44,9598	21,2795	14,4104	55,3531	IP
tr8_25fps	45,7129	23,3316	13,7376	52,4524	IP
tr9_25fps	45,9150	22,8109	13,8075	38,6726	H.264
tr10_25fps	46,2366	24,9340	13,1366	47,7716	H.264
tr11_25fps	46,1750	26,8091	12,6419	56,9119	H.264
tr12_25fps	46,3316	27,6826	12,3599	63,7984	H.264

### 4.3. Diskusija o rezultatima

U tablici 4.2. vidljive su ocjene kvalitete pojedinih video zapisa iz LIVE baze koje su dobivene pomoću odabranih metrika. Kako bi se vrednovali dobiveni rezultati odabranih metrika potrebno je izračunati Pearsonov linearni koeficijent korelacije sa subjektivnim ocjenama kvalitete za iste video zapise. Korelacija predstavlja međusobnu povezanost između različitih pojava predstavljenih vrijednostima dviju varijable. Povezanost znači da je vrijednost jedne varijable moguće s određenom vjerojatnošću predvidjeti na osnovi saznanja vrijednosti druge varijable [38]. Pearsonov linearni koeficijent korelacije između rezultata subjektivne i pojedinačne objektivne metrike računa se prema:

$$r_p = \frac{\sum_{i=1}^n (x_i - x')(y_i - y')}{\sqrt{\sum_{i=1}^n (x_i - x')^2} * \sqrt{\sum_{i=1}^n (y_i - y')^2}} \quad (4-1)$$

gdje je:

- $r_p$  -Pearsonov koeficijent korelacije
- $x_i$  -vrijednost subjektivne ocjene kvalitete video zapisa tj. MOS
- $y_i$  -vrijednost kvalitete dobivena objektnom metodom za pojedini video zapis
- $x'$  -srednja vrijednost svih subjektivnih ocjena za sve video zapise u bazi
- $y'$  -srednja vrijednost svih objektivnih ocjena za sve video zapise u bazi

Koeficijent korelacija kreće se od -1 do 1, gdje 1 predstavlja savršenu pozitivnu korelaciju, a -1 predstavlja savršenu negativnu korelaciju, dok 0 znači da nema korelacije između dviju varijabli. Predznak koeficijenta korelacije govori o smjeru korelacije, a snaga korelacije je ista za oba predznaka [38].

U ovom radu korištena je MATLAB funkcija  $\text{corrcoef}(X,Y)$  [32]. X predstavlja niz subjektivnih ocjena za određeno izobličenje, dok Y predstavlja niz objektivnih ocjena dobivenih uporabom pojedine metrike. Rezultati dobiveni za Pearsonov linearni koeficijent korelacije za pojedine metrike pri određenim izobličenjima nalaze se u tablici 4.3.

**TABLICA 4.3.** Pearsonov linearnim koeficijent korelacije između subjektivnih ocjena i ocjena korištenih objektivnih metrika za IP i H.264 izobličenja i za sve sekvence zajedno.

Metoda	Tip izobličenja		
	IP	H.264	Ukupno
BRISQUE	0.1850	0.1381	0.1221
MSU blocking	0.2508	0.2200	0.1933
MSU blurring	-0.1179	-0.0532	-0.0563

Prema rezultatima iz tablice 4.3. vidljivo je da rezultati BRISQUE, MSU Blocking i MSU Blurring metrika imaju nisku korelaciju s ljudskom procjenom kvalitete video zapisa odnosno sa subjektivnim ocjenama. Kod MSU Blurring metode koeficijent korelacije je negativan jer je skala rezultata kod MSU Blurring metode obrnuta u odnosu na onu kod subjektivne metode. Skala subjektivne metode je u rasponu od 0 do 100, gdje 0 predstavlja najbolju, a 100 najgoru ocjenu, dok kod MSU Blurring metrike raspon je od 0 do 100 gdje 100 predstavlja najbolju, a 0 najgoru ocjenu. MSU Blocking ima najbolju korelaciju zato što je izrađena za mjerenje subjektivnog efekt blokiranja na video zapisu. Ona sadrži heurističku metodu za otkrivanja rubova objekata te se koriste podaci iz prethodnog okvira kako bi se postigla točnost. BRISQUE kao preciznija metrika ima nisku korelaciju iz razloga što je namijenjena za slike, dok je u ovom radu primijenjena na video zapisu, gdje vremenska komponenta videa nije uzeta u obzir.

## 5. ZAKLJUČAK

Ovaj se rad bavi NR metrikama koje samo analiziraju izobličeni video signal bez dostupnosti informacija o referentnom signalu. Odabrane su tri NR metrike za procjenu kvalitete video zapisa iz LIVE baze video signala, BRISQUE, MSU Blocking i MSU Blurring. Općenito, sve 3 metode testirane u ovom radu postižu vrlo nisku korelaciju sa subjektivnim rezultatima. Koeficijent korelacije bi sigurno bio nešto viši kada bi se odradilo nelinearno pridruživanje rezultata metrike subjektivnim rezultatima, no to nije bilo predmet ovog rada.

## LITERATURA

- [1] S. Winkler, P. Mohandas, The Evolution of Video Quality Measurement: from PSNR to Hybrid Metrics, *IEEE Transactions on Broadcasting*, vol. 54, no. 3, 2008, str. 660-668
- [2] S. Daly, The visible difference predictor: an algorithm for the assessment of image fidelity, U: A.B. Watson (eds), *Digital images and human vision*, The MIT, Cambridge, str. 179-206
- [3] Z. Wang, L. Lu, A.C. Bovik, Video quality assessment based on structural distortion measurement, *Signal Processing: Image Communication*, vol. 19, no. 2, 2004, str. 121-132
- [4] A.B. Watson, J. Hu, J.F. McGowan III, DVQ: A digital video quality metric based on human vision, *Journal of Electronic Imaging*, vol. 10, no. 1, 2001, str. 20-29
- [5] C.J. van den Branden Lambrecht, O. Verscheure, Perceptual quality measure using a spatio-temporal model of the human visual system, U: *Proc. SPIE Digital VideoCompression: Algorithms and Technologies*, vol. 2668, 1996, str. 450-461
- [6] S. Winkler, A perceptual distortion metric for digital color video, U: *Proc SPIE Human Vision and Electronic Imaging IV*, vol. 3644, 1999, str. 175-184
- [7] K. T. Tan, M. Ghanbari, D.E. Pearson, An objective measurement tool for MPEG video quality, *Signal Processing*, vol. 70, 1998, str. 279-294
- [8] K.T. Tan, M. Ghanbari, A multi-metric objective picture quality measurement model for MPEG video quality, *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 10, 2000, str. 1208-1213
- [9] S. Rimac-Drlje, M. Vranješ, D. Žagar, Foveated mean squared error – a novel video quality metric, *Multimedia Tools and Applications*, vol. 49, 2010, str. 425-445
- [10] D.M. Chandler, S.S. Hemami, VSNR: A wavelet-based visual signal-to-noise-ratio for natural images, *IEEE Transactions on Image Processing*, vol. 16, 2007, str. 2284-2297
- [11] Z. Wang, E.P. Simoncelli, A.C. Bovik, Multi-scale structural similarity for image quality assessment (Invited paper), U: *Proc. of the IEEE Asilomar Conference on Signals, Systems and Computers*, SAD, 2003.
- [12] K. Seshadrinathan, A.C. Bovik, Motion-based perceptual quality assessment of video, U: *Proc. SPIE Human Vision and Electronic Imaging*, vol. 7240, 2009.
- [13] M.H. Pinson, S. Wolf, A new standardized method for objectively measuring video quality, *IEEE Transactions on Broadcasting*, vol. 50, 2004, str. 312-322

- [14] Y. Horita, T. Miyata, I.P. Gunawan, T. Murai, M. Ghanbari, Evaluation model considering static-temporal quality degradation and human memory for SSCQE video quality, U: *Proc. SPIE Visual Communications and Image Processing*, vol. 5150, 2003, str. 1601-1611
- [15] I.P. Gunawan, M. Ghanbari, Reduced-reference Video Quality Assessment Using Discriminative Local Harmonic Strength With Motion Consideration, *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 18, 2008, str. 71-83
- [16] C.T.E.R. Hewage, M.G. Martini, Reduced-reference quality assessment for 3D video compression and transmission, *IEEE Transactions on Consumer Electronics*, vol. 57, 2011, str. 1185-1193
- [17] I.P. Gunawan, M. Ghanbari, Efficient Reduced-Reference Video Quality Meter, *IEEE Transactions on Broadcasting*, vol. 54, 2008, str. 669-679
- [18] S. Yang, Reduced reference MPEG-2 picture quality measure based on ratio of DCT coefficients, *Electronics Letters*, vol. 47, 2011, str. 382-383
- [19] S. Winkler, A. Sharma, D: McNally, Perceptual video quality and blockiness metrics for multimedia streaming applications (Invited paper), U: *Proc. of International Symposium on Wireless Personal Multimedia Communications*, Danksa, 2001, str. 547-552
- [20] H.R. Wu, M. Yuen, A generalized block-edge impairment metric for video coding, *IEEE Signal Processing Letters*, vol. 4, 1997, str. 317-320
- [21] V. Baroncini, A. Perotti, Single-ended objective quality assessment of DTV, U: *Proc. SPIE Multimedia Systems and Applications*, vol. 3845, 1999, str. 244-253
- [22] Z. Wang, A. C. Bovik, B.L. Evans, Blind measurement of blocking artifacts in images, U: *Proc. of International Conference on Image Processing 3*, Kanada, str. 981-984
- [23] T. Vlachos, Detection of blocking artifacts in compressed videos, *Electronics Letters*, vol. 36, 2000, str. 1106-1108
- [24] <https://link.springer.com/article/10.1186/1687-5281-2014-40> (kolovoz, 2017.)
- [25] <http://www.diva-portal.org/smash/get/diva2:833836/FULLTEXT01.pdf> (kolovoz, 2017)
- [26] A. Mittal, A. K. Moorthy, A. C. Bovik, No-Reference Image Quality Assessment in the Spatial Domain, *IEEE Transactions on Image Processing*, vol. 21, no. 12, 2012.
- [27] [http://www.compression.ru/video/quality\\_measure/video\\_measurement\\_tool.html#nav](http://www.compression.ru/video/quality_measure/video_measurement_tool.html#nav) (kolovoz, 2017.)
- [28] SH. Hong, L. Wang, TK. Truong, TC. Lin, and LJ. Wang, "Novel approaches to the parametric cubic-spline interpolation," *IEEE Trans. Image Process.*, pp. 1233-1241, March 2013.



- [29] <http://ieeexplore.ieee.org/document/6325335/> (kolovoz, 2017)
- [30] <http://www.itiis.org/digital-library/manuscript/352> (kolovoz, 2017)
- [31] <http://live.ece.utexas.edu/research/quality/nrqa.htm> (kolovoz, 2017)
- [32] [http://www.ijesit.com/Volume%202/Issue%205/IJESIT201305\\_06.pdf](http://www.ijesit.com/Volume%202/Issue%205/IJESIT201305_06.pdf) (kolovoz, 2017)
- [33] A. K. Moorthy, A. C. Bovik, Blind Image Quality Assessment: From Natural Scene Statistics to Perceptual Quality, IEEE Transactions on Image Processing, vol. 20, no. 12, 2011.
- [34] <http://www.ni.com/white-paper/13306/en/> (kolovoz, 2017.)
- [35] <http://www.cns.nyu.edu/~lcv/ssim/> (kolovoz, 2017.)
- [36] [http://live.ece.utexas.edu/research/quality/live\\_video.html](http://live.ece.utexas.edu/research/quality/live_video.html) (kolovoz, 2017.)
- [37] <https://www.mathworks.com/matlabcentral/fileexchange/36417-yuv-files-reading-and-converting> (kolovoz, 2017.)
- [38] <http://www.statisticshowto.com/what-is-the-pearson-correlation-coefficient/> (kolovoz, 2017.)
- [39] <https://www.mathworks.com/help/matlab/ref/corrcoef.html> (kolovoz, 2017.)

## **POPIS I OPIS UPOTRIJEBLJENIH KRATICA**

ACR - Absolute Category Rating

AGGD - Asymmetric Generalized Gaussian Distribution

BRISQUE -Blind/Referenceless Image Spatial QUality Evaluator

DCR - Degradation Category Rating

DIIVINE -Distortion Identification-based Image Verity and INtegrity Evaluation

DS -Double Stimulus

FF -Fast Fading

FR - Full-Reference

GB - Gaussian Blur

GSM -Gaussian Scale Mixure

IQA - Image Quality Assessment

MSCN - Mean Subtracted Contrast Normalized

MSE -Mean Squared Error

NR -No Reference

PDV -Packet Delay Variation

PSNR -Peak Signal to Noise Ratio

RR – Reduced- Reference

SS -Single Stimulus

VQMT -Video Quality Measurement Tool

WN -White Noise

## SAŽETAK

U ovom radu objašnjene su vrste metrika za određivanje ocjene kvalitete video signala te njihova podjela. Najopćenitija podjela metrika je na subjektivne i objektivne metrike. Ovaj rad se bavi objektivnim metrikama. Detaljnije su obrađene NR metrike. Metrike koje su u radu testirane su: BRISQUE, MSU Blocking i MSU Blurring. Testiranje je provedeno na LIVE bazi video zapisa iz koje su se koristili video zapisi samo s IP i H.264 tipovima izobličenja. Na temelju dobivenih rezultata vrši se usporedba rezultata pojedine metrike sa subjektivnim rezultatima. Nijedna od analiziranih metrika se nije pokazala dovoljno točnom za procjenu kvalitete video signala s IP i H.264 tipovima izobličenja.

### KLJUČNE RIJEČI:

ocjena kvalitete video signala, NR metrike , BRISQUE, MSU Blocking, MSU Blurring.

# **VIDEO QUALITY ASSESSMENT THAT DO NOT REQUIRE ACCESS TO THE REFERENCE SIGNAL**

## **ABSTRACT**

In this paper the types of video quality metrics and their division are presented. The most common metric division is on subjective and objective metrics. This paper deals with objective metrics. Detailed explanations are given for NR metrics. Metrics that were tested are: BRISQUE, MSU Blocking and MSU Blurring. Testing was performed for signals from LIVE video quality database, from which videos only with IP and H.264 types of distortion were used. Based on the obtained results, a comparison of the results of a particular metric with the subjective results is performed. None of the analyzed metrics has shown to be accurate enough to assess the video signal quality with IP and H.264 types of distortion.

## **KEYWORDS:**

video quality evaluation, NR metric, BRISQUE, MSU Blocking, MSU Blurring.

## **ŽIVOTOPIS**

Sebastian Schneider rođen je 23.studenog 1995. godine u Sisku. Završio je osnovnu školu Stjepana Kefelje u Kutini. Nakon završene osnovne škole upisao je Tehničku školu Kutina. Sudjelovao je u projektu SOELA tijekom školovanja u Tehničkoj školi Kutina. Maturirao 2014. godine i upisao preddiplomski sveučilišni studij elektrotehnike na Elektrotehničkom fakultetu u Osijeku.